

PA052: Úvod do systémové biologie

David Šafránek

13.10.2011

Tento projekt je spolufinancován Evropským sociálním fondem a státním rozpočtem České republiky.



Obsah

Biologické sítě

Rekonstrukce biologických sítí

Ontologie biologických znalostí

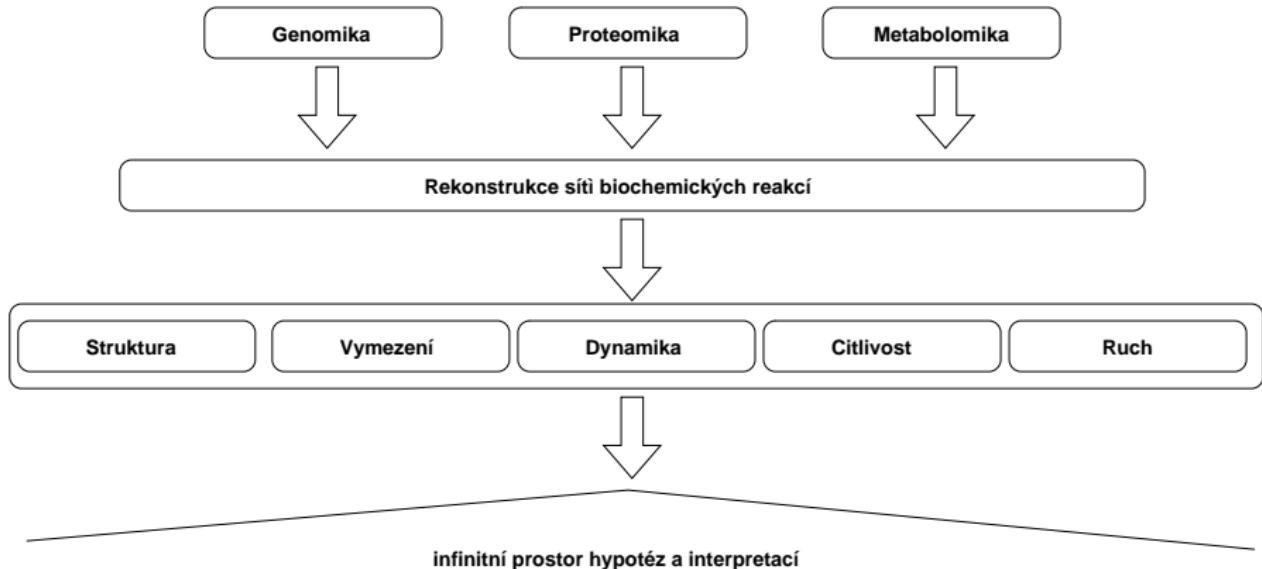
Obsah

Biologické sítě

Rekonstrukce biologických sítí

Ontologie biologických znalostí

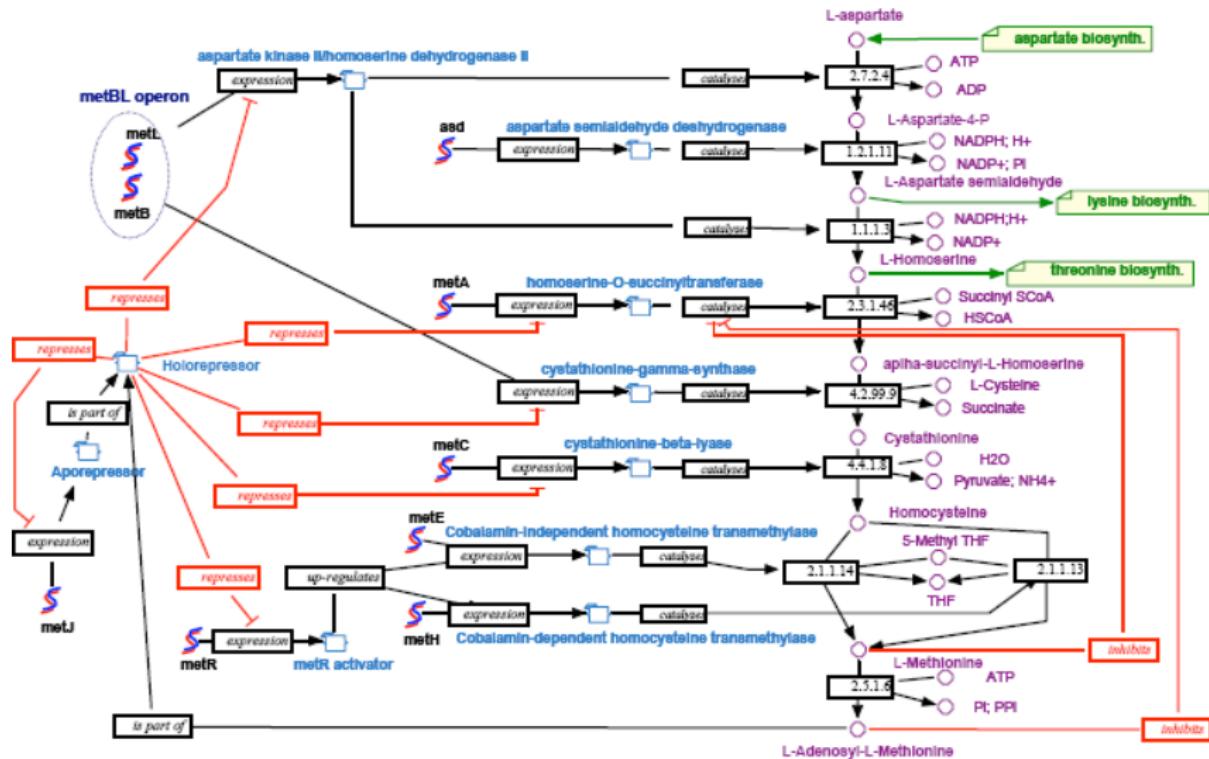
Rekonstrukce biologických sítí v kontextu SB



Biologické sítě a dráhy

- biochemická interakce molekul popsaná grafem
- uzly
 - molekuly/komplexy biochemických látek
 - biochemické reakce
- hrany
 - regulace (aktivace, represe, katalýza)
 - příslušnost k reakci (produkt, zdroj)
- dráhy — zaměřené na určitá specifika (látky, reakce)
 - typicky signální dráhy
- síť — komplexní interakce
- různé úrovně abstrakce, různé notace, např. Kohn's diagrams
<http://www.nature.com/msb/journal/v2/n1/full/msb4100044.html>

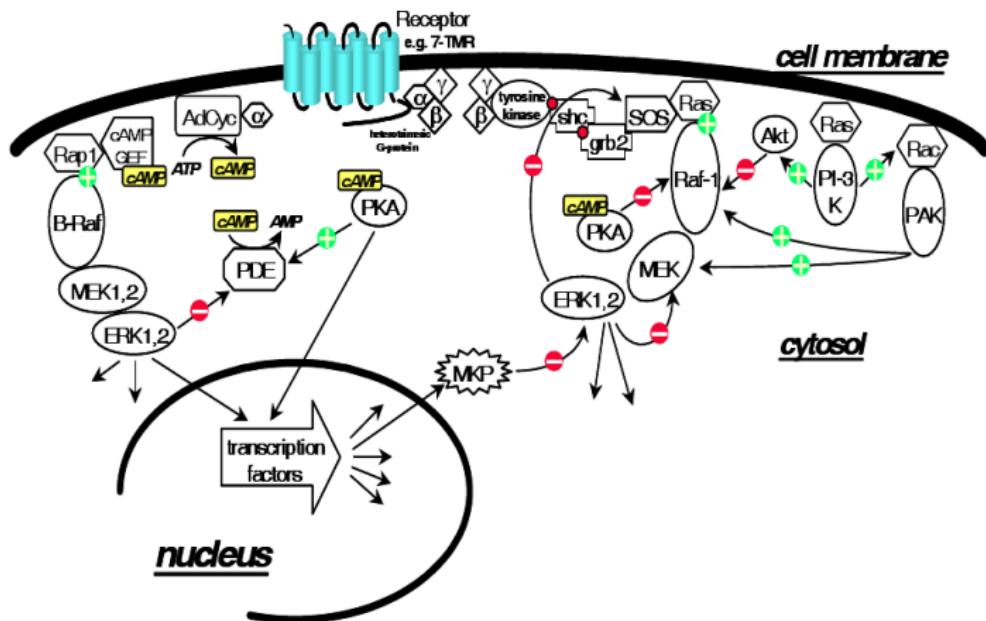
Příklad komponenty biologické sítě



Biologické sítě a dráhy

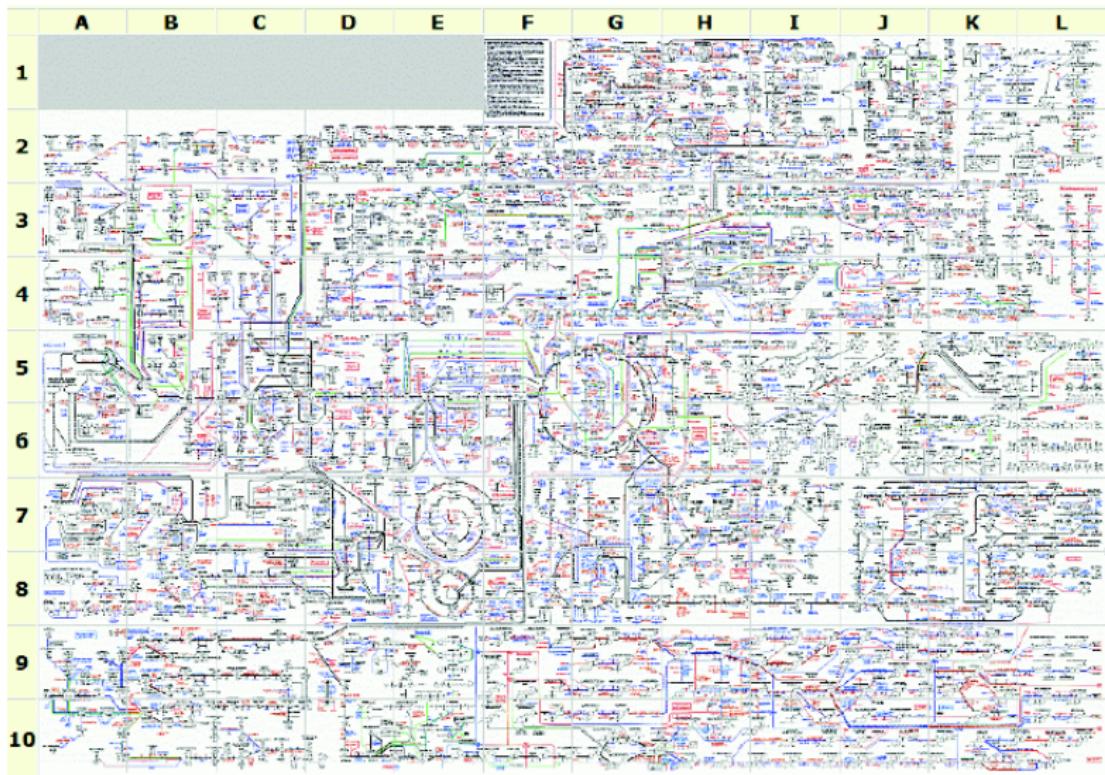
- komplexy vzájemně interagujících chemických reakcí
- klíčem ke studiu fyziologie organismu
- představují základní informaci pro tvorbu *in silico* modelu
- v průběhu evoluce může docházet k přidávání/ubírání hran

Biologické sítě a dráhy

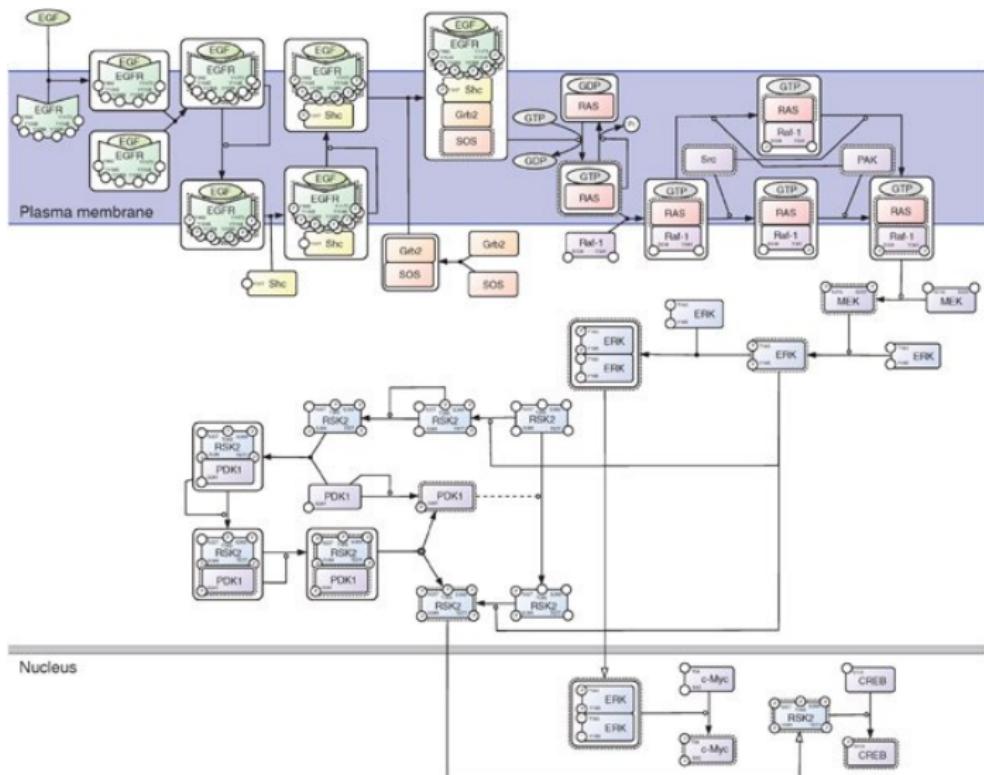


- neformální notace
- vyvíjejí se standardy — SBGN (podporuje např. CellDesigner)

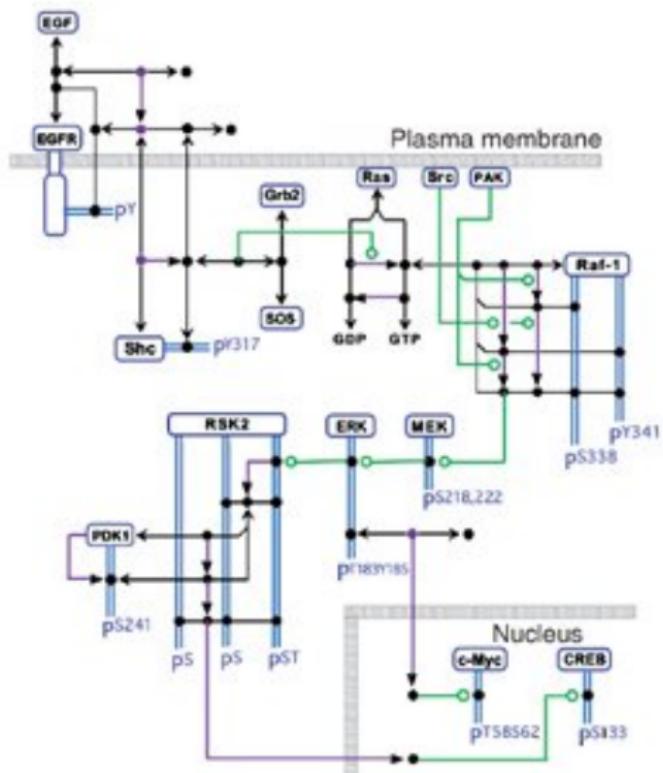
Metabolická síť – ad hoc diagram



Signální síť – SBGN



Signální síť – Kohnova mapa



Obsah

Biologické sítě

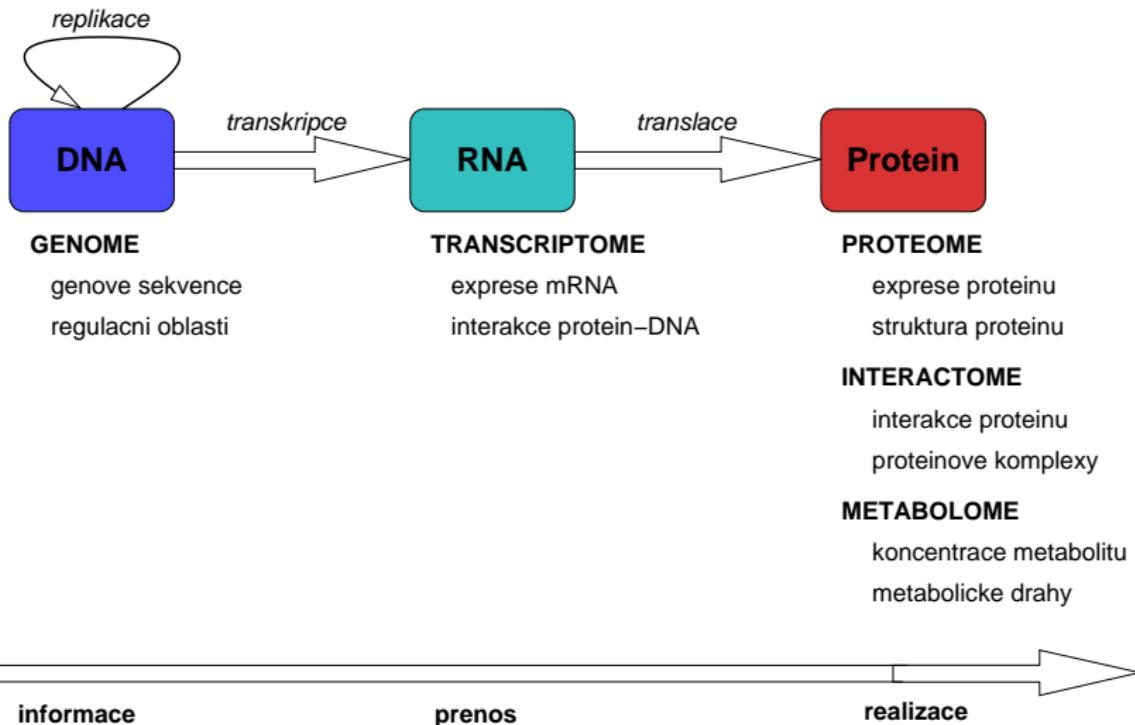
Rekonstrukce biologických sítí

Ontologie biologických znalostí

Původ biologických dat

- tradiční biochemie a genetika
 - výsledky reduktionistického období biologie
 - forma: vědecké články
 - získání dat: dolováním znalostí z textů (text mining)
- low-throughput technologie
 - separace proteinů prostřednictvím antigenů
 - genové reportery
- high-throughput technologie
 - sekvenování genomu
 - měření exprese genů na DNA mikročipu
 - hmotnostní spektrometrie
 - proteomika a metabolomika

Rekonstrukce v kontextu centrálního dogmatu



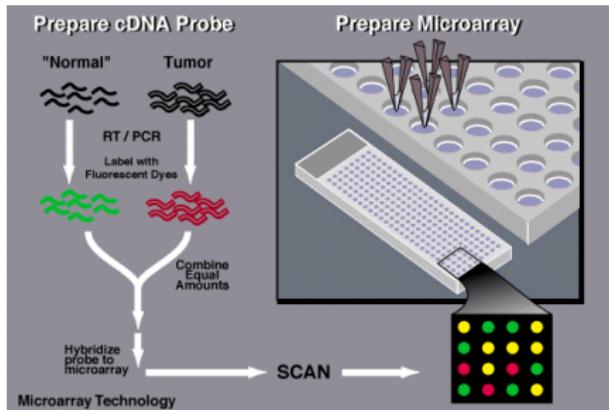
Data na úrovni RNA

- exprese mRNA
 - DNA microarray: high-throughput data (genome-scale expresní profily), typicky na populační úrovni
 - individuální informace pomocí genových reportérů (lze i na úrovni buňky)
 - srovnání s knock-out/knock-in mutacemi
 - dolování hypotéz o regulačních interakcích (shlukováním profilů)
 - transkriptom poskytuje hrubý odhad o expresi proteinů, nemusí být vypořádající (post-transkripční modifikace, regulace degradace mRNA, splicing)
- interakce protein-DNA
 - ChIP-chip (chromatin immunoprecipitation + microarray): přímá detekce vazeb transkripčních faktorů na DNA

K rekonstrukci regulační sítě je nezbytné integrovat data z úrovni genomu a transkriptomu.

Měření mRNA exprese

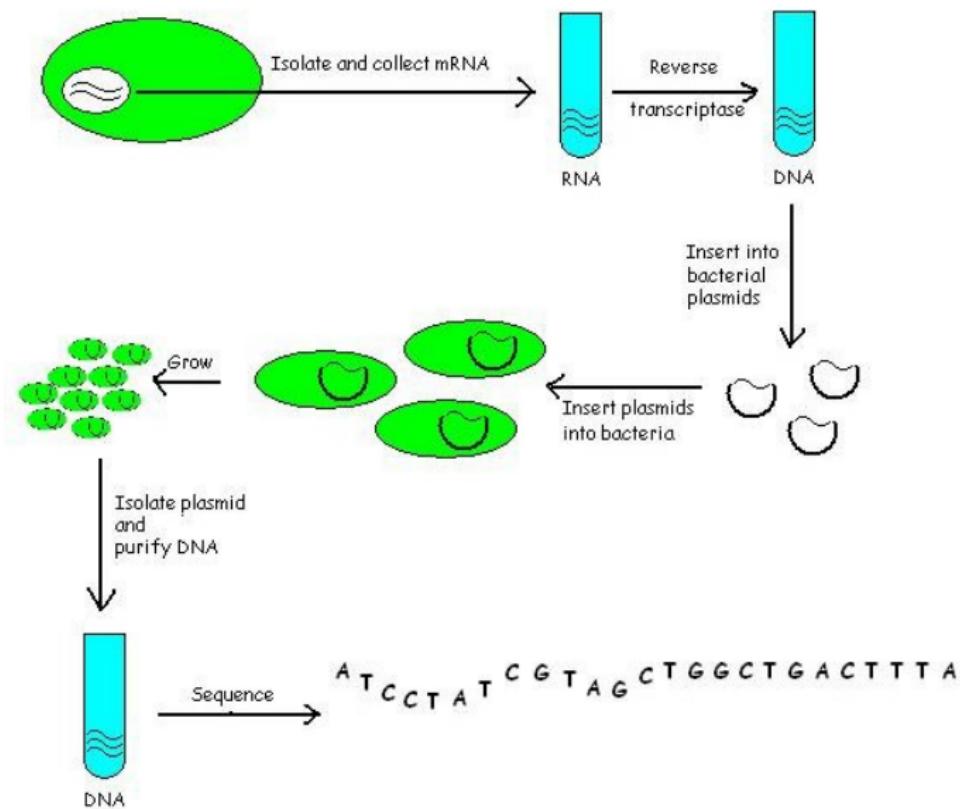
- nejpoužívanějším nástrojem je technologie DNA microarray
 - v daném okamžiku je paralelně nasamplována exprese všech genů v genomu příslušného organismu
 - postaveno na relativním srovnání minimálně dvou různých vzorků
 - exprese v přítomnosti vs. nepřítomnosti O_2
 - exprese při knock-outu určitého genu vs. normální stav
 - ...



Postup při DNA microarray experimentu

1. konstrukce čipu z cDNA knihovny (amplifikace a rozmístění sekvencí)
2. odběr celkové mRNA z experimentálních vzorků (typicky 2)
3. reverzní transkripce do cDNA asociované s fluorescenčním barvivem
4. hybridizace odebrané cDNA s cDNA na čipu
5. omytí čipu a oskenování výsledku
6. analýza dat
7. komerční čipy používají místo cDNA knihovny skupinu oligonukleotidů pro každý gen
⇒ pouze jeden vzorek mRNA je analyzován na jednom čipu (porovnání více identicky připravených čipů)

Reverzní transkripce cDNA a amplifikace



Využití Polymerase Chain Reaction (PCR)

- umožňuje replikaci určité části DNA (forma amplifikace)
- DNA je zahřátím rozdělena
- úsek DNA je označen párem oligonukleotidů (15-25 bazí)
 - při snížení teploty hybridizace oligonukleotidů s řetězcem DNA
 - doplnění zbývající sekvence DNA prostřednictvím RNA polymerázy
- <http://www.dnalc.org/resources/animations/pcr.html>
- lze využít i pro mRNA: RT-PCR (reverse transcription PCR)
 - reverzní transkripce mRNA do cDNA
 - amplifikace cDNA (PCR)

Databáze microarray dat

- Stanford Microarray Database – různé pohledy na data, filtrace

<http://smd.stanford.edu/cgi-bin/cluster/dr GetData.pl>

- ArrayExpress – statisticky zpracovaná data

<http://www.ebi.ac.uk/gxa/>

- Gene Expression Omnibus (GEO)

<http://www.ncbi.nih.gov/geo/>

- MUSC DNA Microarray Database

<http://proteogenomics.musc.edu/ma/>

- GenExpDB (E. Coli specifická data)

<http://genexpdb.ou.edu/>

GenExpDB

Welcome to the *E. coli* Community's Gene Expression Database (GenExpDB)

Hosted by the University of Oklahoma

Instructions: Search *E. coli* GenExpDB using either gene, b-number or location (multiple entries separate by comma or space).

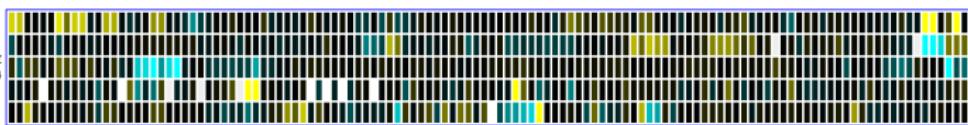
Example: edd • b3517 • lacZ, lacY, lacZ • 416366 (location) • reset

Search by: Operon Regulon Sigma Text Experiment

MultiFun

Query

Pearson

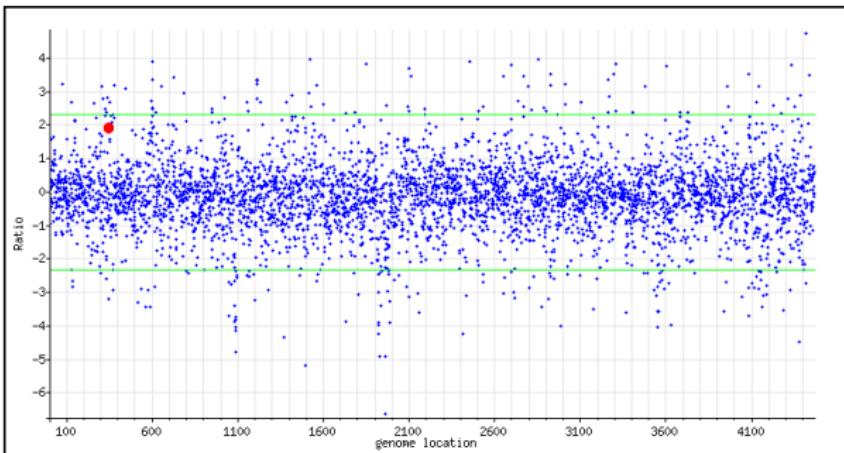


GSE15406

ppGpp0 GraL / ppGpp control (short term)

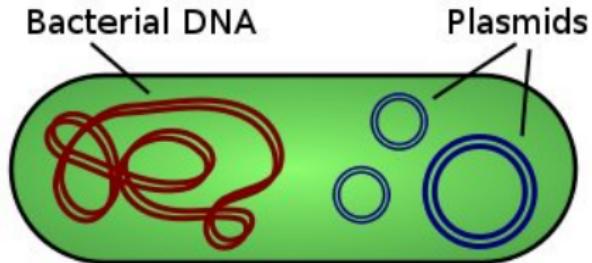
Data Count: 4368

[close](#)

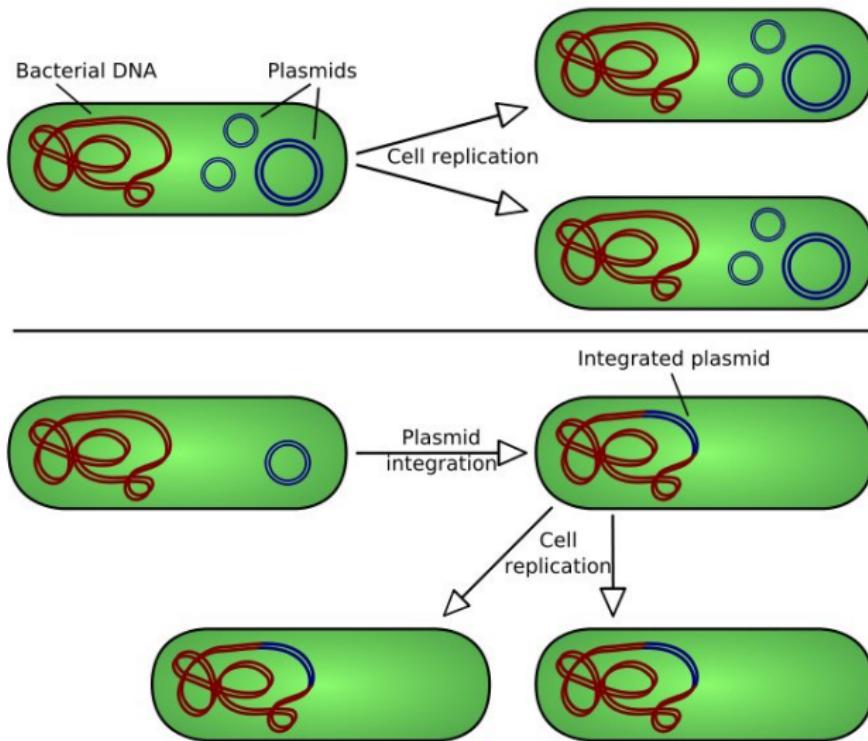


Měření mRNA exprese pomocí genových reportérů

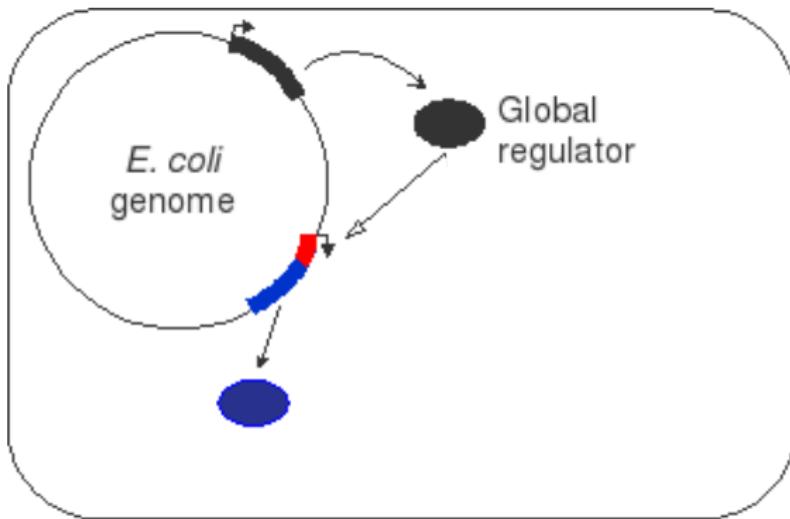
- genovým reporterem se rozumí umělá subsekvence DNA zavedená do buňky
 - formou persistentního syntetického plasmidu (externí molekula DNA zavedená do buňky)
 - modifikací chromozomu (prostřednictvím plasmidu)



Zavedení plasmidu do buňky

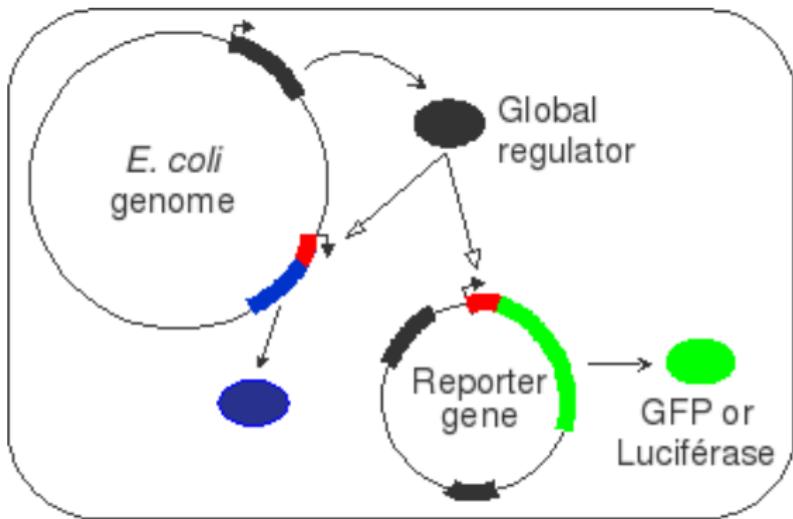


Schema aplikace genového reporteru



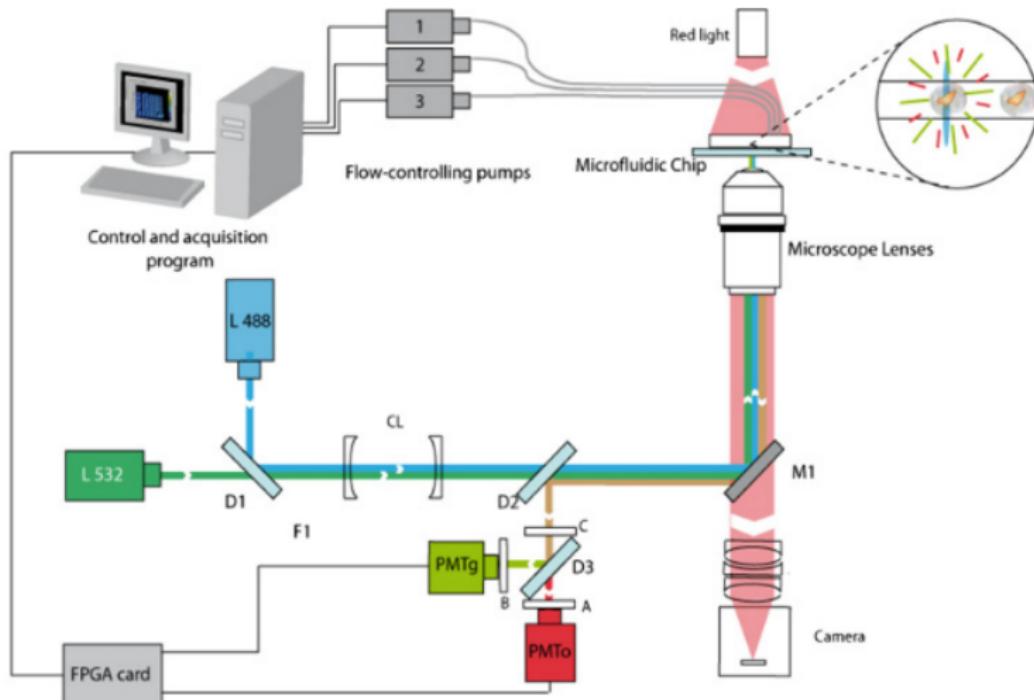
- genový reporter převádí aktivitu na určitém promotoru na měřitelný jev (nejčastěji fluorescence – GFP, luciferase)
- měření reportovaného jevu probíhá na populační úrovni, lze i single-cell (digital microfluidics)

Schema aplikace genového reporteru



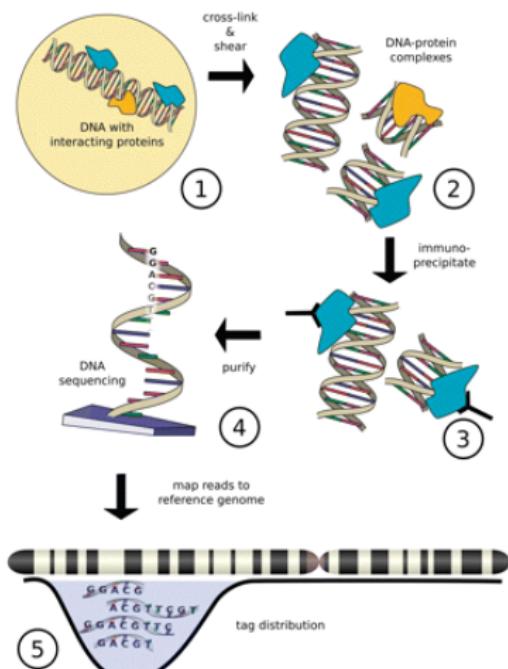
- genový reporter převádí aktivitu na určitém promotoru na měřitelný jev (nejčastěji fluorescence – GFP, luciferase)
- měření reportovaného jevu probíhá na populační úrovni, lze i single-cell (digital microfluidics)

Mikrofluidická soustava pro genové reportéry



Baret, Jean-Christophe; Beck, Yannick; Billas-Massobrio, Isabelle; Moras, Dino; Griffiths, Andrew D. Quantitative Cell-Based Reporter Gene Assays Using Droplet-Based Microfluidics. *Chemistry & biology* doi:10.1016/j.chembiol.2010.04.010 (volume 17 issue 5 pp.528 - 536)

Detekce vazeb protein-DNA



Szalkowski, A.M., and Schmid, C.D.(2010). Rapid innovation in ChIP-seq peak-calling algorithms is outdistancing benchmarking efforts. *Briefings in Bioinformatics*.

Data rekonstruovaných regulačních sítí

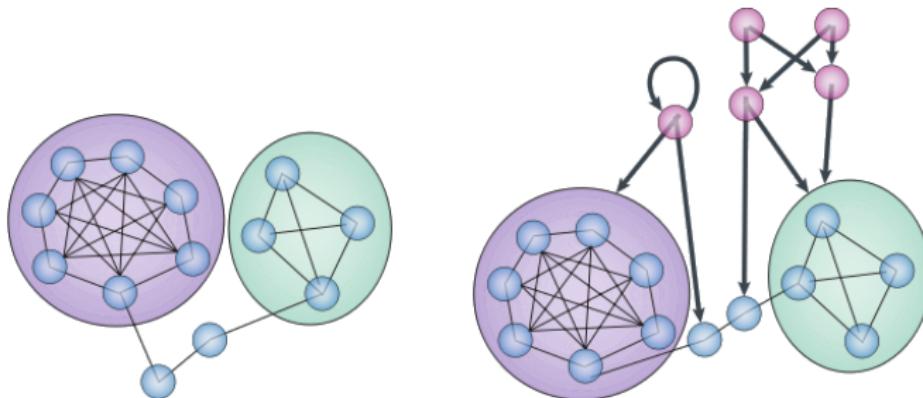
| | <i>E. coli</i> | <i>S. cerevisiae</i> | <i>S. cerevisiae</i> (ChIP-chip) |
|---------------------|----------------|----------------------|----------------------------------|
| regulující geny | 123 | 109 | 203 |
| regulované geny | 451 | 418 | 1296 |
| regulační interakce | 1468 | 945 | 3353 |

- *E. coli* – RegulonDB (<http://regulondb.ccg.unam.mx/>)
- *S. cerevisiae* –
http://web.wi.mit.edu/young/regulator_network/

Christopher T. Harbison, et al. Transcriptional regulatory code of a eukaryotic genome. Nature 431, 99-104 (2 September 2004). doi:10.1038/nature02800.

S Shen-Orr, R Milo, S Mangan & U Alon. Network motifs in the transcriptional regulation network of Escherichia coli. Nature Genetics, 31:64-68 (2002).

Úrovně pohledu na regulační interakce



koexpresní síť

uzly: geny

hrany: podobný expresní profil

genová regulační síť

uzly: geny a TF

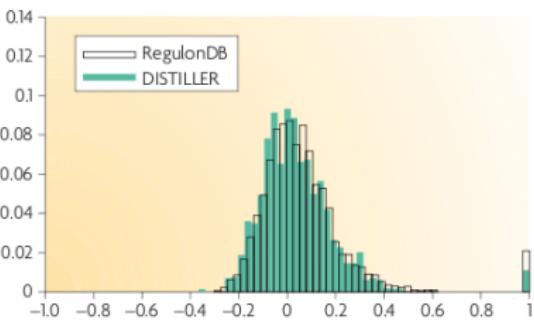
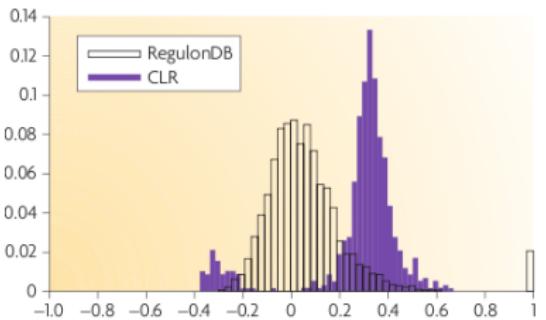
hrany: regulace

Problémy rekonstrukce

- uvažme *E. coli*
⇒ 4500 genů, z toho 300 kódujících známý TF
- máme 4500×300 možností interakcí ...
- navíc dochází ke kombinatorickým regulacím
- nutno uplatnit optimalizační strategie:
 - shlukování expresních profilů (clustering)
 - integrace dat
 - metody řízené dotazy (query-driven reconstruction pomocí bayesovských závislostí)

Problémy rekonstrukce

Srovnání integračních a expresních metod

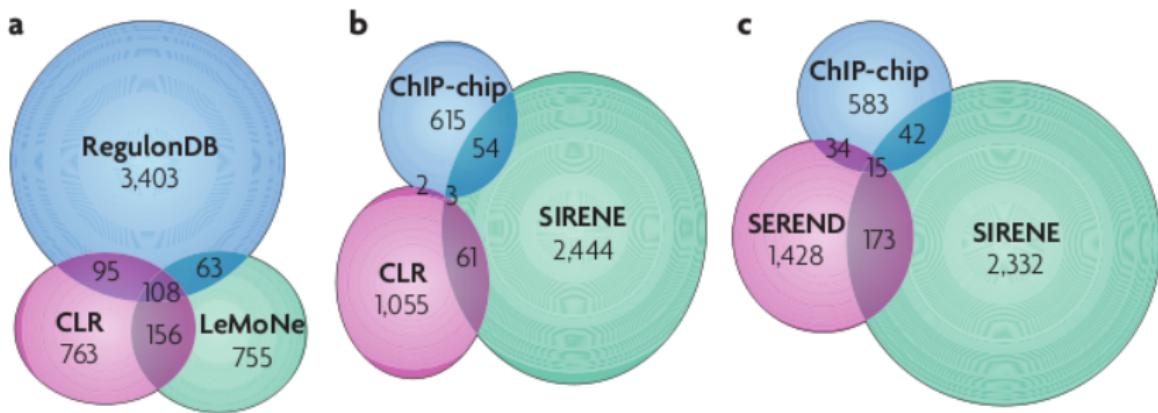


Riet De Smet & Kathleen Marchal. Advantages and limitations of current network inference methods. Nature Reviews Microbiology 8, 717-729 (October 2010). doi:10.1038/nrmicro2419

- DISTILLER – nástroj postavený na integrační metodě (integrace expresních a interakčních dat)
- CLR – nástroj postavený na výpočtu korelace expresních dat

Problémy rekonstrukce

Divergence metod

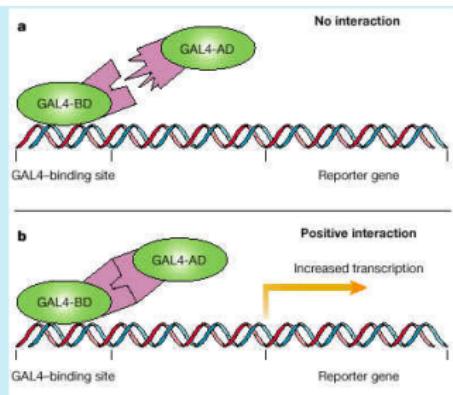


Riet De Smet & Kathleen Marchal. Advantages and limitations of current network inference methods. Nature Reviews Microbiology 8, 717-729 (October 2010). doi:10.1038/nrmicro2419

- LeMoNe – nástroj postavený na strojovém učení z expresních profilů (shlukování)
- SIRENE – řízené strojové učení
- SEREND – částečně řízené strojové učení + integrace dat

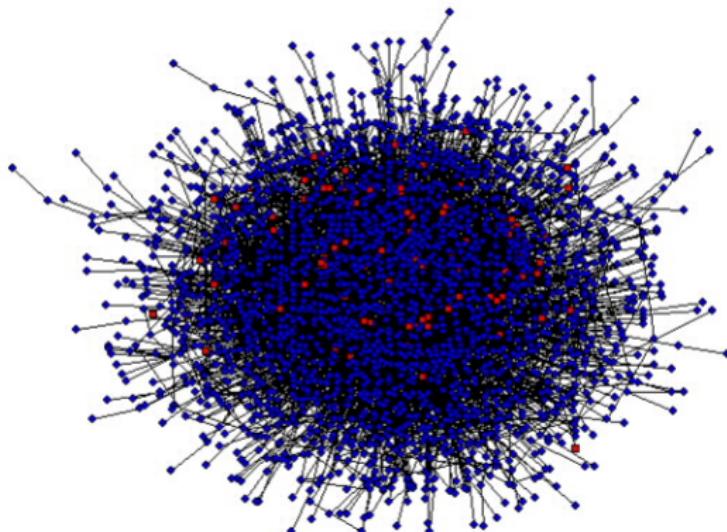
Data na úrovni proteomu a interaktomu

- exprese proteinů
 - proteinové chipy (problémové – např. proteinové interakce závislé na termodynamických podmírkách)
 - hmotnostní spektrometrie (separace chromatografií, ionizace a měření rychlosti pohybu mezi elektrodami)
- detekce interakcí protein-protein
 - proteinové chipy (univerzální použití)
 - Y2H (yeast two-hybrid system)



Data na úrovni proteomu a interaktomu

Sítě proteinových interakcí

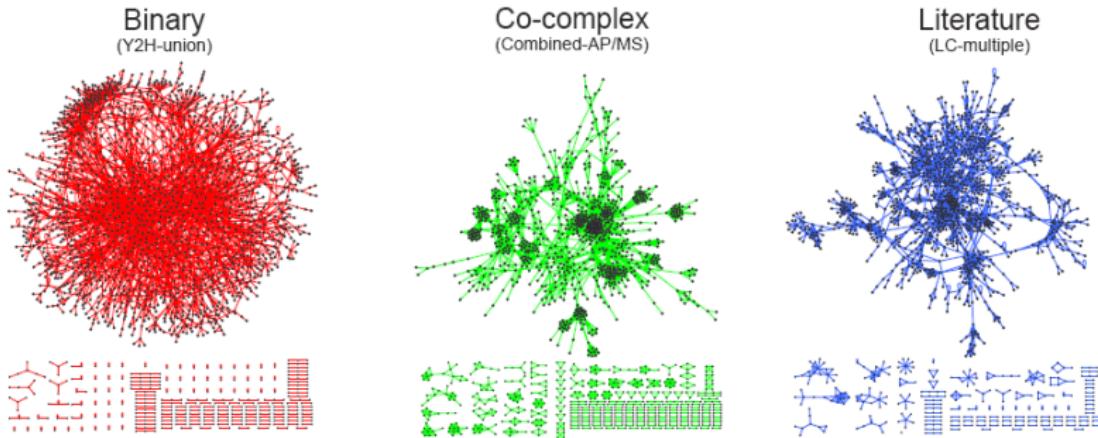


interakce proteinů člověka

zdroj: <http://www.estradalab.org/research/index.html>

Data na úrovni proteomu a interaktomu

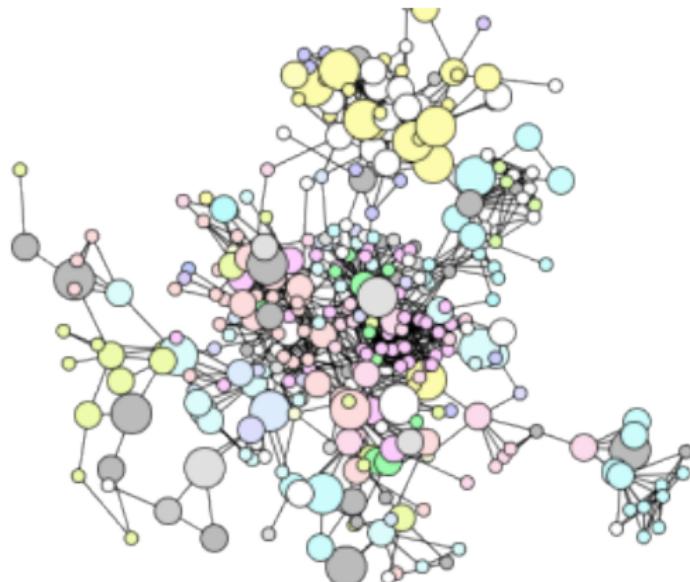
Interakce proteinů *S. cerevisiae*



Yeast Interactome Database –
http:// interactome.dfci.harvard.edu/S_cerevisiae/

Data na úrovni proteomu a interaktomu

Interakce proteinů *E. coli*



Bacteriome – <http://www.compsysbio.org/bacteriome/>

Data na úrovni proteomu a interaktomu

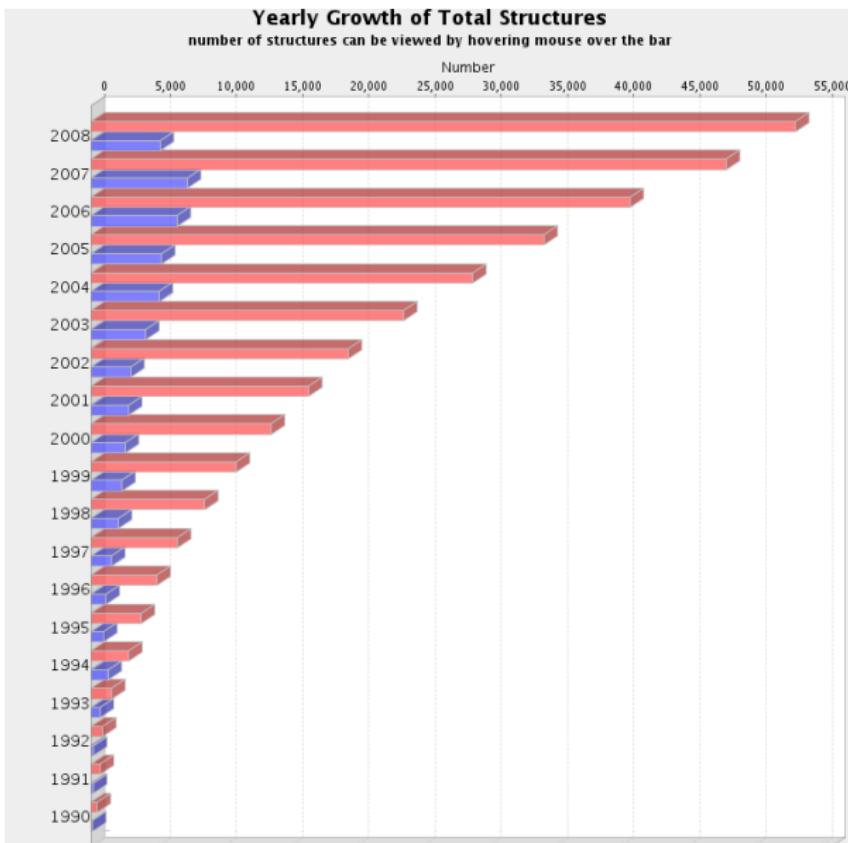
Další zdroje

- *C. elegans* –
http:// interactome.dfci.harvard.edu/C_elegans/
- *Drosophila* – <http://www.droidb.org/>

Proteinová databanka PDB

- databáze 3D strukturálních dat proteinů a nukleových kyselin
- založena 1971
- veřejný přístup
- <http://www.rcsb.org/pdb/>
- PDB formát souborů –
<http://www.wwpdb.org/documentation/format30>
- primární struktura (sekvence aminokyselin) – FASTA formát
- vyhledávání proteinů dle sekvencí – BLAST –
<http://www.ebi.ac.uk/Tools/blast2/>

Proteinová databanka PDB



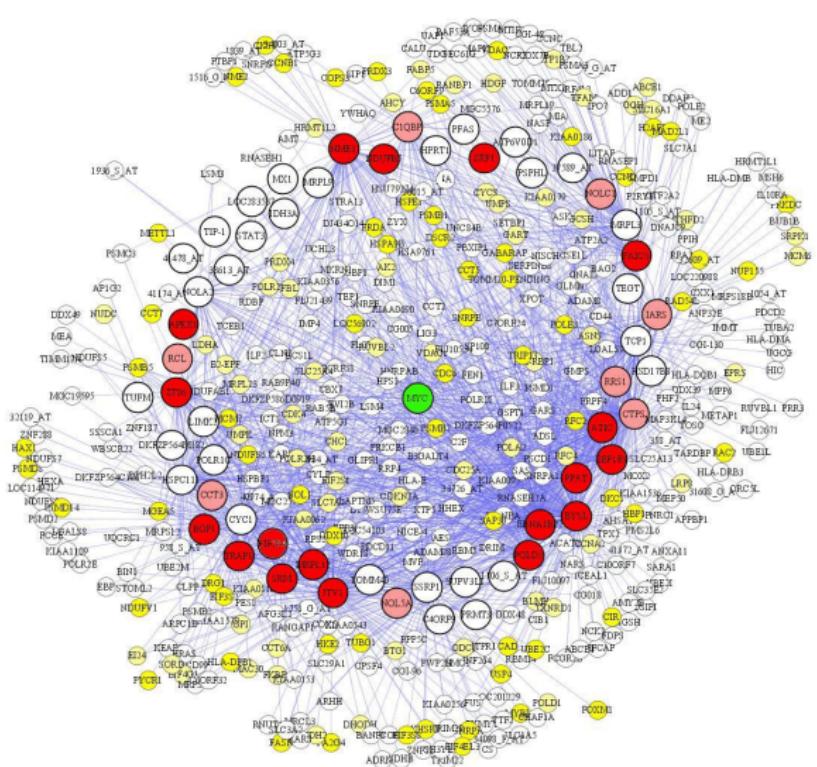
Data na úrovni metabolomu

- interakce mezi metabolismy determinovány chemicky (proteiny ve funkci enzymů)
- měření metabolitů pomocí hmotnostní spektrometrie
- měření aktivity enzymů na úrovni proteomu/transkriptomu
- integrace s daty na nižších úrovních
- data získaná z literatury a genoých sekvencí (pro daný organismus)
- data dostupná ve veřejných databázích
- problémy mohou vznikat díky chybné identifikaci sekvencí

Data na úrovni metabolomu

| Organismus | # enz. genů | # metabolitů | # reakcí |
|-------------------------------|-------------|--------------|----------|
| <i>E. coli</i> | 904 | 625 | 931 |
| <i>S. cerevisiae</i> | 750 | 646 | 1149 |
| <i>Staphylococcus aureus</i> | 619 | 571 | 640 |
| <i>Haemophilus influenzae</i> | 362 | 343 | 488 |
| <i>Helicobacter pylori</i> | 268 | 340 | 444 |

Metabolické sítě



zdroj: <http://www.di.unipi.it/~braccia/ToolCode/>

KEGG – Kyoto Encyclopedia of Genes and Genomes

- integrativní databáze genových produktů
- genový prostor
⇒ GENES, GENOME, ORTHOLOGY, Organisms
- chemický prostor
⇒ COMPOUND, GLYCAN, REACTION, ENZYME, LIGAND
- systémový prostor
⇒ PATHWAY, BRITE, DISEASE, DRUG
- každý pojem má jednoznačné ID
- zachycena ortologie (podobnost) genů
- genový prostor čerpá aktuálně z několika zdrojů

KEGG – ORGANISMS



GENOME: Escherichia coli K-12 MG1655

[Help](#)

| | | |
|-----------------------------------|---|-------------------------------|
| Entry | T00007 | Complete Genome |
| Name | eco, E.coli, ECOLI, 511145 | |
| Definition | Escherichia coli K-12 MG1655 | |
| Annotation | manual | Show organism |
| Taxonomy Lineage | TAX:511145 Bacteria; Proteobacteria; Gammaproteobacteria; Enterobacteriales; Enterobacteriaceae; Escherichia | Taxonomy |
| Data source | RefSeq (Project:225) | |
| Original DB | Wisconsin Pasteur RegulonDB EcoGene ECOCYC | |
| Chromosome Sequence Length | Circular RS:NC_000913 4639675 | |
| Statistics | Number of nucleotides: 4639675 Number of protein genes: 4144 Number of RNA genes: 175 | |
| Reference Authors | PMID:9278503 Blattner FR, et al. | |
| Title | The complete genome sequence of Escherichia coli K-12. | |
| Journal | Science 277:1453-74 (1997) | |

KEGG – ORGANISMS



[Bright menu]

▼ ▼ ▼ ▼ ▼

► **Eukaryotes** (248)

▼ **Prokaryotes** (1189)

▼ **Bacteria** (1099)

- ▼ **Gamma proteobacteria** (265)
 - ▼ **Escherichia** (31)
 - eco** Escherichia coli K-12 MG1655
 - ecl** Escherichia coli K-12 K12
 - ecd** Escherichia coli K-12 DH10B
 - ebs** Escherichia coli K-12 MG4100(MuLuc) B2952
 - ecc** Escherichia coli O157:H7 EDL933 (EHEC)
 - esc** Escherichia coli O157:H7 Sakai (EHEC)
 - ecf** Escherichia coli O157:H7 EC4115 (EHEC)
 - estw** Escherichia coli O157:H7 TM41359 (EHEC)
 - esi** Escherichia coli O26:H11 11366 (EHEC)
 - sol** Escherichia coli O111:H- 11126 (EHEC)
 - sol** Escherichia coli O103:H2 12009 (EHEC)
 - seq** Escherichia coli O127:H6 E2348/69 (EPEC)
 - sok** Escherichia coli O55:H7 CB9615 (EPEC)
 - sec** Escherichia coli O6:E2:H1 CPT073 (UPEC)
 - sep** Escherichia coli O6:E15:H3 536 (UPEC)
 - sci** Escherichia coli O18:E1:H7 UTI189 (UPEC)
 - scv** Escherichia coli O1:E1:H7 (APEC)
 - esc** Escherichia coli O9:H8 (commensal)
 - esc** Escherichia coli O139:H28 E24377A (ETEC)
 - escm** Escherichia coli SBE-3-5 (environmental)
 - escy** Escherichia coli O152:H28 SK11 (commensal)
 - escr** Escherichia coli O8:IA11 (commensal)
 - escq** Escherichia coli O81 ED1a (commensal)
 - esc** Escherichia coli 55989 (EPEC)
 - ect** Escherichia coli O7:E1 IA139 (ExPEC)
 - euw** Escherichia coli O17:E28:H18 UH4026 (ExPEC)
 - ecz** Escherichia coli O45:E1:H7 S88 (ExPEC)
 - ecl** Escherichia coli C ATCC 8739
 - ebr** Escherichia coli B PEL606
 - ebd** Escherichia coli BL21-Gold(DE3)pLysS AG
 - efc** Escherichia fergusonii

► **Salmonella** (16)

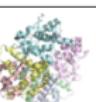
► **Yersinia** (13)

► **Shigella** (7)

► **Pectobacterium** (3)

KEGG – GENES

Kegg Escherichia coli K-12 MG1655: b1891 Help

| | |
|------------|--|
| Entry | b1891 CDS E.coli |
| Gene name | flhC, ECK1892, flaI, JW1880 |
| Definition | DNA-binding transcriptional dual regulator with FlhD |
| Orthology | KO2402 flagellar transcriptional activator FlhC |
| Pathway | eco02020 Two-component system eco02040 Flagellar assembly |
| Class | Environmental Information Processing; Signal Transduction; Two-component system [PATH:eco02020] Cellular Processes; Cell Motility; Flagellar assembly [PATH:eco02040] BRITE hierarchy |
| SSDB | Ortholog Paralog Gene cluster GFIT |
| Motif | Pfam: FlhC Motif |
| Other DBs | NCBI-GI: 16129843 NCBI-GeneID: 947280 RegulonDB: B1891 EcoGene: EG10319 ECOCYC: EG10319 UniProt: POABY7 |
| Structure | PDB: 2AVU Thumbnails  Jmol |

http://www.genome.jp/dbget-bin/www_bget?eco:b1891

KEGG – ORTHOLOGY

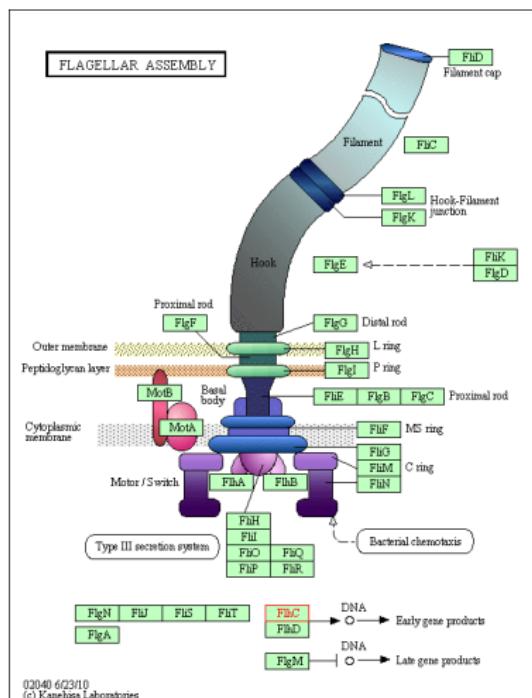


ORTHOLOGY: K02402

[Help](#)

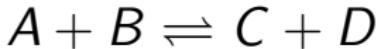
| | | |
|-------------------|--|---------------------------------|
| Entry | K02402 | K0 |
| Name | flhC | |
| Definition | flagellar transcriptional activator FlhC | |
| Pathway | ko02020 Two-component system ko02040 Flagellar assembly | |
| Class | Environmental Information Processing; Signal Transduction; Two-component system [PATH: ko02020] Cellular Processes; Cell Motility; Bacterial motility proteins [BR: ko02035] Cellular Processes; Cell Motility; Flagellar assembly [PATH: ko02040] | BRITE hierarchy |
| Genes | ECO: b1891 (flhC) ECJ: JW1880 (flhC) EBW: BWG_1705 (flhC) ECE: Z2945 (flhC) ECS: ECs2601 ECF: ECH74115_2630 (flhC) ETW: ECSP_2465 (flhC) EOJ: EC026_2743 (flhC) EOI: EC0111_2477 (flhC) EOH: EC0103_2153 (flhC) ECG: E2348C_2014 (flhC) EOK: G2583_2344 (flhC) ECC: c2306 (flhC) ECP: ECP_1835 ECI: UTI89_C2094 (flhC) | |

KEGG – PATHWAYS



Data (bio)chemických reakcí

- vstupy reakce – substráty (reaktanty)
- výstupy reakce – produkty

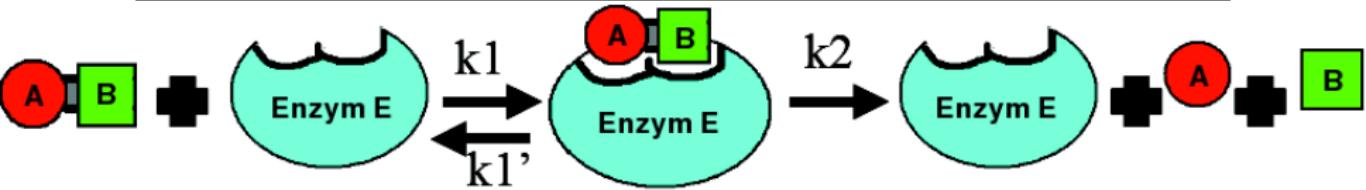
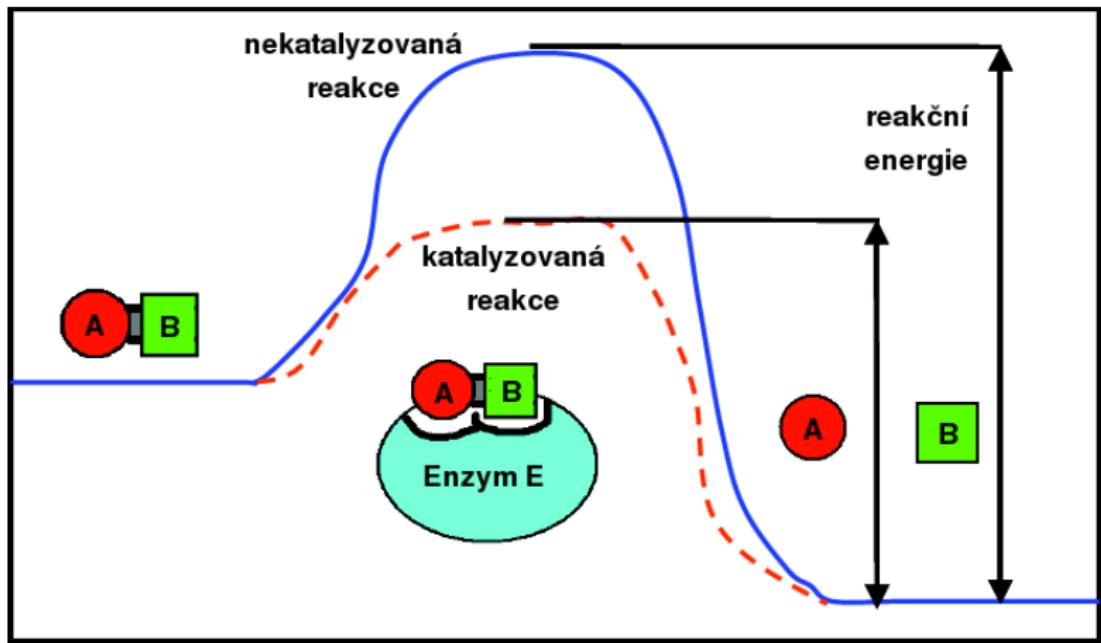


- řídící látky (specifické proteiny — enzymy, koenzymy)
 - katalýza – urychlení/zpomalení reakce (aktivátory/inhibitory)
 - zesilování katalytických účinků enzymů koenzymy
 - např. katalytické urychlení rozpadu:



- pilířem je komplex katalytických reakcí – metabolismus
- metabolismus umožňuje zpracování a přeměnu energie

Energetický průběh reakce



Složitost metabolismu

- v e.coli je více než 1000 reakcí
- opakující se motivy
 - zpracování ATP (adenozintrifosfát) – zisk energie
 - omezené množství aktivních meziproduktů
 - jen cca 100 molekul má zásadní funkci
 - omezené množství typů reakcí
- individuální reakce jsou typicky jednoduché (omezené množství substrátů/produktů)

Klasifikace reakcí

- každá reakce identifikována EC číslem
- definováno dle názvosloví enzymů

<http://www.chem.qmw.ac.uk/iubmb/enzyme>

EC 3.2.1.23

typ reakce

druh substrátu

subidentifikace

popis akceptoru

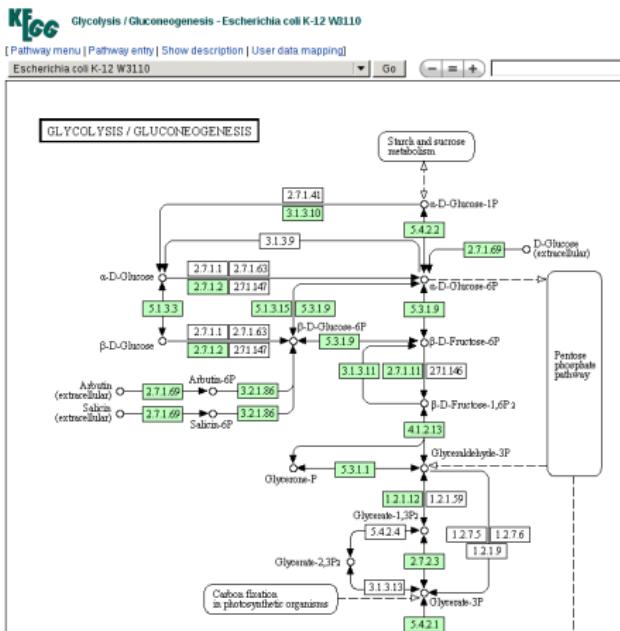
Klasifikace reakcí

- celkem 8 typů reakcí (enzymů)
 - oxydoreduktázy, transferázy, hydrolázy, ...
- EC 3.2.1.23 – β -galaktocidáza
 - hydrolýza inhibující tvorbu laktózy, součást galaktózové metabolické dráhy
 - http://www.ebi.ac.uk/thornton-srv/databases/cgi-bin/enzymes/GetPage.pl?ec_number=3.2.1.23

Databáze enzymů, metabolických drah

- BRENDA — <http://www.brenda-enzymes.org/>
⇒ zahrnuje kvantitativní data
- IntEnz — <http://www.ebi.ac.uk/intenz/>
⇒ zaměřeno na názvosloví
- KEGG — <http://www.genome.jp/kegg/>
⇒ schemata metabolických drah
<http://www.genome.jp/kegg/pathway.html>
- MetaCyc — <http://metacyc.org/>

KEGG – PATHWAYS



[http:](http://www.genome.jp/kegg-bin/show_pathway?org_name=ecj&mapno=00010&mapscale=&show_description=hide)

//www.genome.jp/kegg-bin/show_pathway?org_name=ecj&mapno=00010&mapscale=&show_description=hide

Cvičení

Uvažujme sekvenci aminokyselin (FASTA formát):

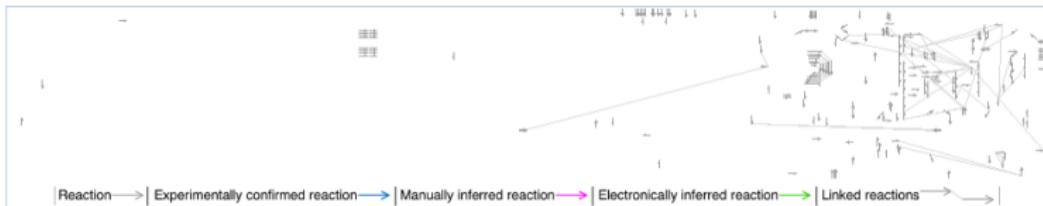
```
SVVEEHGQLSISNGELVNERGEQVQLKGMSHGLQWYGQ
FVNYESMKWLRRDWGINFRAAMYTSSGGYIDDPS
VKEKVKEAVEAAIDLDIYVIIDWHILSDNDPNIYK
EEAKDFFDEMSELYGDYPNVIYEIANEPNGSDVTW
GNQIKPYAEEVPIIIRNNDPNNIIIVGTGTWSQDV
HHAADNQLADPNVMYAFHFYAGTHGQNLRDQVDYA
LDQGAAIFVSEWGTSAATGDGGVFLDEAQVWIDFM
DERNLSWANWSLTHKDESSAALMPGANPTGGWTEA
ELSPSGTFVREKIRE
```

- najděte na <http://www.ebi.ac.uk/intenz/>
- prozkumejte relevantní dráhy na
<http://www.genome.jp/kegg/>

Reactome

Reactome - a curated knowledgebase of biological pathways

The data displayed is for **Escherichia coli** ▾ Use the menu to change the species. Check for cross-species comparison.



| | | | |
|---|-------------------------------------|---------------------------------------|---|
| Apoptosis | Axon guidance | Biological oxidations | Botulinum neurotoxicity |
| Cell junction organization | Cell Cycle Checkpoints | Cell Cycle, Mitotic | Chromosome Maintenance |
| DNA Repair | DNA Replication | Diabetes pathways | Respiratory electron transport, ATP synthesis by chemiosmotic coupling, and heat production by uncoupling proteins. |
| Gene Expression | Hemostasis | HIV Infection | Interactions of the immunoglobulin superfamily (IgSF) member proteins |
| Influenza Infection | Integration of energy metabolism | Integrin cell surface interactions | Membrane Trafficking |
| Metabolism of amino acids and derivatives | Metabolism of carbohydrates | Metabolism of lipids and lipoproteins | Metabolism of nitric oxide |
| Metabolism of nucleotides | Metabolism of porphyrins | Metabolism of proteins | Metabolism of RNA |
| Metabolism of vitamins and cofactors | Muscle contraction | mRNA Processing | Myogenesis |
| Pyruvate metabolism and Citric Acid (TCA) cycle | Regulation of beta-cell development | Regulatory RNA pathways | Signaling by BMP |
| Signaling by EGFR | Signaling by FGFR | Signaling by GPCR | Signaling by PDGF |
| Signaling in immune system | Signaling by Insulin receptor | Signalling by NGF | Signaling by Notch |

<http://www.reactome.org/>

Specificky zaměřené zdroje dat

- EcoCyc — <http://ecocyc.org> - E. coli K12
- SGD — <http://www.yeastgenome.org/>
- WORMBASE – http://www.sanger.ac.uk/Projects/C_elegans/WORMBASE/
- FlyBase — <http://flybase.org/>
- ...

Obsah

Biologické sítě

Rekonstrukce biologických sítí

Ontologie biologických znalostí

Databáze odborných článků

- PubMed Entrez – vyhledávání v odborných biologických/lékařských článcích

<http://www.ncbi.nlm.nih.gov/sites/entrez>

- Maintained by U.S. National Library of Medicine
- obsahuje okolo 15 mil. referencí
- zahrnuje články více než 4000 časopisů
- slovník pojmu MeSH

Ontologie genů a genových produktů

- nutnost systematicky uchopit genom, genové produkty a funkce (interaktom)
- akumulace biologických dat
 - decentralizovaný proces
 - paralelní proces
- problém: nejednoznačné popisy téhož objektu, procesu
 - např. proteolýza vs. (řízená degradace proteinů)
- od roku 1998 vývoj Gene Ontology
⇒ <http://geneontology.org>

Gene Ontology

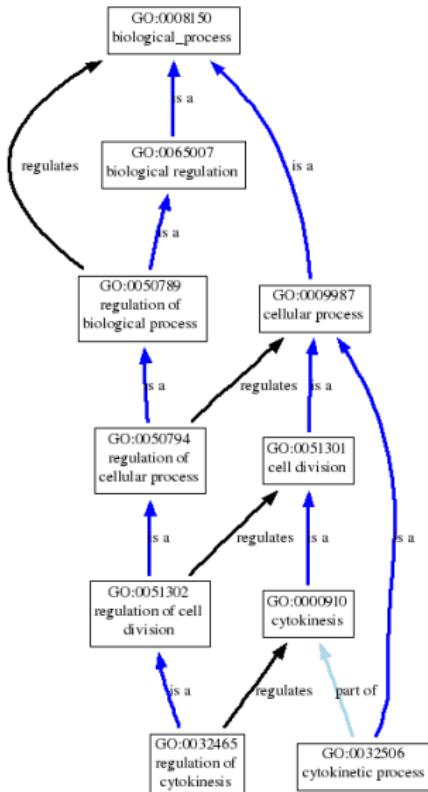
- cílem je ucelený systematický popis genových produktů a jejich funkcí
- ontologie představuje systematický slovník pojmu
 - hierarchický pohled na data včetně vazeb mezi nimi (DAG)
 - zachycení synonym
- GO obsahuje 3 kategorie (DAGy):
 - biological process
 - cellular component
 - molecular function

Gene Ontology

- respektuje standard OBO a OWL (W3C) pro strukturu a reprezentaci ontologií
 - <http://obofoundry.org/>
 - <http://www.w3.org/TR/owl-features/>
- každý uzel představuje jednoznačný pojem (množinu synonym)
⇒ jednoznačně reprezentován ID (tzv. GO termem)
- různé typy relací mezi uzly:
 - part_of, is_a, located_in, derived_from, ...
 - viz <http://obofoundry.org/ro/>

Gene Ontology

Příklad podgrafa GO



Nástroje pro Gene Ontology

- on-line i off-line vyhledávače v GO
- statistické testy na overrepräsentaci dané množiny genů v pojmech GO
 - GOstat –
<http://gostat.wehi.edu.au/cgi-bin/goStat.pl>
 - DAVID – <http://david.abcc.ncifcrf.gov/>
 - BiNGO –
<http://www.psb.ugent.be/cbd/papers/BiNGO/Home.html>
- mapování microarray dat na ontologický strom
 - eGOn – <http://www.genetools.no/>
 - High-Throughput GoMiner –
<http://discover.nci.nih.gov/gominer/htgm.jsp>
 - Meta Gene Profiler (MetaGP) – <http://metagp.ism.ac.jp/>
- ...

Literatura

-  Kitano, H. *Foundations of Systems Biology*. MIT Press, 2001.
-  Palsson, B. *Systems Biology: Properties of Reconstructed Networks*. Cambridge University Press, 2006.
-  Rigoutsos, I. and Stephanopoulos, G. *Systems Biology Volume II: Networks, Models, and Applications*. Oxford University Press, 2004.
-  Klipp, E. et al. *Systems Biology in Practise: Concepts, Implementation and Application*. Wiley-VCH, 2005.